

УДК 004.93'1

*С.М. Аваков<sup>1</sup>, А.А. Воронов<sup>2</sup>, В.В. Ганченко<sup>2</sup>, А.А. Дудкин<sup>2</sup>, А.И. Дедков<sup>1</sup>, В.Г. Шоломицкий<sup>1</sup>*

<sup>1</sup>КБТЭМ-ОМО, Беларусь

пр. Партизанский, 2, г. Минск, 220012

<sup>2</sup>Объединенный институт проблем информатики НАН Беларуси, Беларусь

ул. Сурганова, 6, г. Минск, 220012

## МЕТОДЫ ИСКУССТВЕННОГО ИНТЕЛЕКТА В ПРОГРАММНОМ КОМПЛЕКСЕ УПРАВЛЕНИЯ ОБОРУДОВАНИЕМ КОНТРОЛЯ КРИТИЧЕСКИХ РАЗМЕРОВ (ПК УОККР) НА БАЗЕ СИСТЕМ МАШИННОГО ЗРЕНИЯ

*S. Avakaw<sup>1</sup>, A. Voranau<sup>2</sup>, V. Ganchenko<sup>2</sup>, A. Doudkin<sup>2</sup>, A. Dedkov<sup>1</sup>, V. Sholomicki<sup>1</sup>*

<sup>1</sup>KBTEM-OMO, Belarus,

2, Partisansky Ave., Minsk, 220012

<sup>2</sup>United Institute of Informatics Problems NAS Belarus, Belarus,

6, Surganov Str., Minsk, 220012

## METHODS OF ARTIFICIAL INTELLIGENCE IN THE SOFTWARE MANAGEMENT SYSTEM FOR CRITICAL SIZES CONTROL EQUIPMENT ON THE BASIS OF COMPUTER VISION

В данной работе описываются функциональные требования и структура программного комплекса управления оборудованием контроля критических размеров на базе систем машинного зрения. Методы искусственного интеллекта, реализованные в данном комплексе, включают искусственные нейронные сети типа Network-in-Network и технологию глубинного обучения. Описаны преимущества архитектуры сети Network-in-Network, а также ее использование для решения задач анализа изображений интегральных микросхем. Применение архитектуры нейронных сетей Network-in-Network позволяет эффективно идентифицировать дефекты, что особенно важно для разработки программного обеспечения установок контроля изготовления сверхбольших интегральных схем (СБИС) по субмикронным технологиям.

**Ключевые слова:** нейронная сеть, СБИС, NiN, машинное зрение

In this paper the functional requirements and the structure of software control system for equipment of critical sizes inspection on the basis of computer vision are described. The artificial intelligence methods including Network-in-Network type neural networks and deep learning were applied for solving problems of analyzing images. The advantages of the architecture of Network-in-Network are considered. Application of Network-in-Network technology allows identifying effectively defects that is especially important for software engineering for equipment of critical sizes inspection of VLSI manufacturing based on submicron technology.

**Keywords:** neural networks, VLSI, NiN, Computer Vision

### Введение

Актуальной задачей при разработке и выпуске конкурентоспособных наукоемких изделий микроэлектроники является создание современной научно-технической и производственно-технологической базы производства: интегральных микросхем (ИС) и полупроводниковых приборов (ПП), спроектированных по субмикронным нормам, а также оптико-механического, контрольно-измерительного и сборочного оборудования.

Обновление технологического потенциала электронного машиностроения яв-

ляется основой для повышения конкурентоспособности других отраслей народного хозяйства. Современные средства разработки электронных схем направлены на сокращение времени освоения и запуска в производство новых изделий, а также на понижение стоимости цифровой аппаратуры при ее массовом производстве. Такую возможность и обеспечивает названная выше технологическая база, в том числе системы машинного (технического) зрения, которые являются составной частью современной технологии проектирования и производства ИС.

В связи с переходом на субмикронные нормы проектирования и усложнением самих ИС возникает необходимость решения задач обработки, хранения, приема и передачи больших объемов данных с использованием современных интерфейсов, для чего требуется разработка оригинальных подходов, методов и алгоритмов цифровой обработки изображений и приборов контроля технологических процессов литографии, компьютерных методов и алгоритмов анализа получаемых данных, которые в совокупности позволят обеспечить качественную обработку процессов фотолитографии при изготовлении СБИС по субмикронным нормам.

#### **Функции и архитектура ПК УОККР**

ПК УОККР обеспечивает возможность выполнения следующих функций:

- предобработки изображений с учетом конструкторско-технологических ограничений;
- обработки и анализа изображений с поддержкой оборудования видеозахвата сторонних производителей;
- анализа изображений для контроля конструкторско-технологических ограничений;
- хранения и доступа к данным с возможностью импорта и экспорта данных в различных форматах: для этого используется СУБД MySQL;
- синтезатора программы для автоматического режима работы;
- управления механизмами сторонних производителей;
- визуализации данных.

Главными зарубежными аналогами предлагаемого ПК УОККР являются программные комплексы Olympus MicroSuite FIVE компании Olympus Corporation (Japan) и NIS-Elements Microscope Imaging Software компании Nikon Instruments Inc. (USA).

В разрабатываемом ПК УОККР реализуются основные функции названных выше двух программных комплексов ведущих фирм-производителей аналогов, а также ряд дополнительных функций:

- поиск фрагментов по образцу;
- откат действий, создание резервных копий и сеансовых контрольных точек.

Основную функциональность опишем диаграммой прецедентов или вариантов использования. Прецеденты можно условно разделить на основные и вспомогательные.

Основными прецедентами использования ПК УОККР являются:

- загрузка объекта исследования (полупроводниковой пластины или фотошаблона) – подготовка объекта исследования для дальнейшей работы (предварительная ориентация в пространстве, перемещение в рабочую зону);
- выгрузка объекта исследования – удаление объекта исследования из рабочей зоны в хранилище (контейнер, кассету);
- инициализация установки и базирование механизмов – загрузка в установку данных, описывающих исходное состояние оборудования для решения конкретной задачи, и установка механизмов в соответствующее состояние/положение;
- управление перемещениями координатного стола – формирование обобщенных команд для управления движением координатного стола;
- совмещение и ориентация – привязка системы отсчета и координатной системы объекта к координатной системе установки;
- контроль и измерение размеров – запуск алгоритмов контроля и измерения размеров;
- автоматическое измерение – запуск алгоритмов автоматического измерения размеров;
- определение размеров элементов – запуск алгоритмов определения размеров изображения;
- управление механизмами – подготовка команд управления оборудованием (метакоманд) и соответствующих параметров;

- формирование управляющих команд – преобразование в формат метакоманд, требуемых тем либо иным микроконтроллером управления оборудованием;
- создание программы контроля и измерений для автоматического режима – формирование списка управляющих воздействий с соответствующими параметрами и их сохранение в виде файла либо записи в базе данных;
- создание карты-структуры объекта (объектом может служить как пластина, так и шаблон) – подготовка описания структуры объекта для дальнейшего его исследования (кадры, модули);
- сохранение результатов контроля и измерений – компоновка результатов

работы ПК в структуру, предназначенную для дальнейшего хранения в базе данных и последующее сохранение полученного блока данных с использованием СУБД.

Вспомогательные прецеденты (идентификация пользователя) требуются для разграничения доступа к функциональности ПК.

Для эффективной реализации приведенных выше функций была разработана следующая архитектура комплекса (рис.1).

ПК УОККР совместим с оборудованием, выпускаемым ОАО «КБТЭМ-ОМО» и интегрируется в единый технологический цикл.

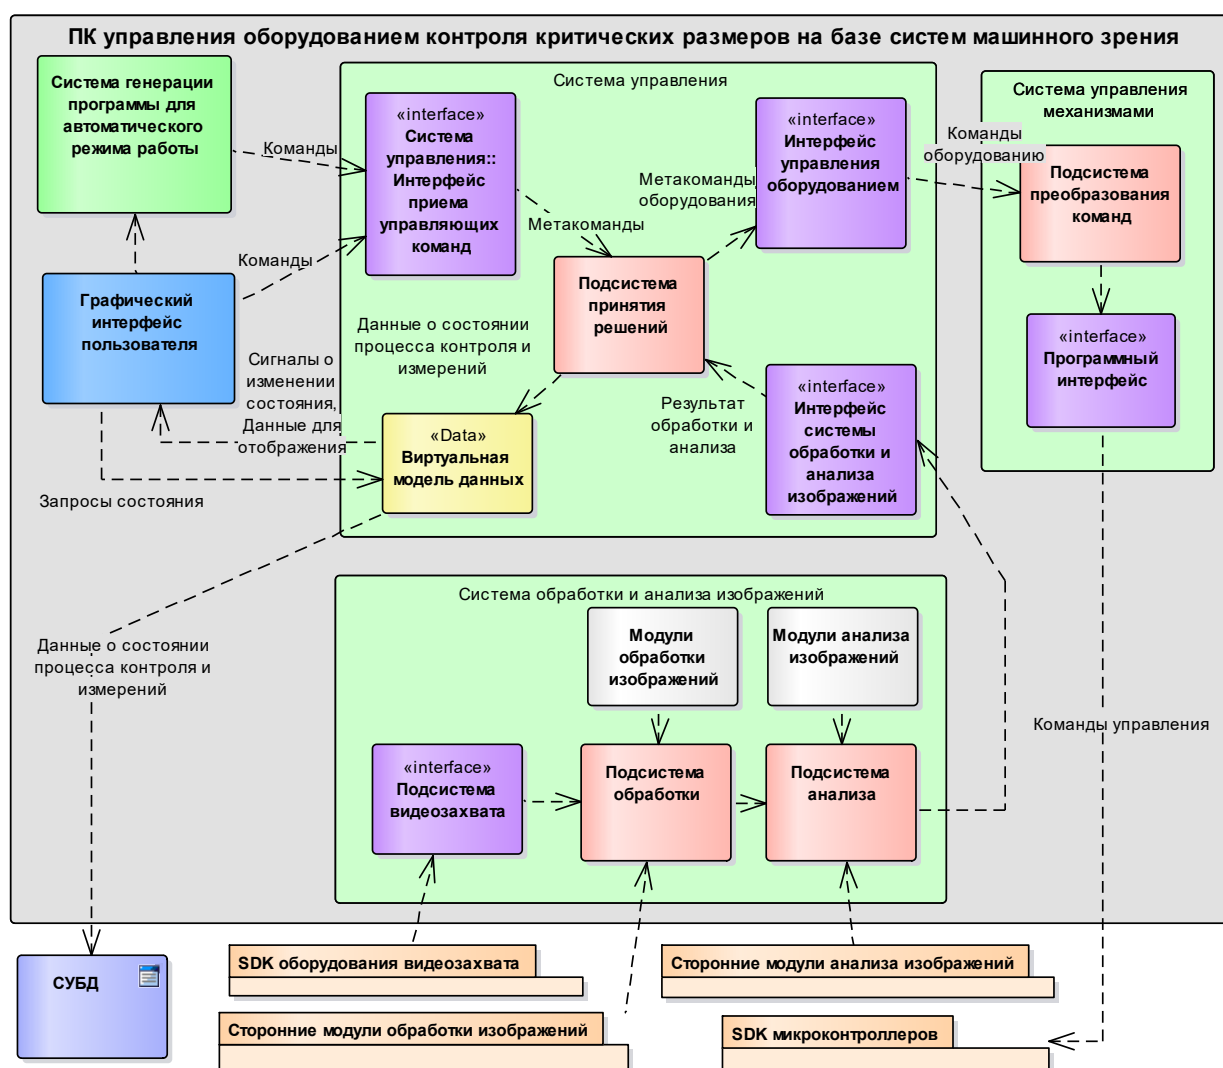


Рис. 1. Архитектура ПК УОККР

### Исходные данные

Изображения топологий интегральных микросхем, полученные при увеличении, отличаются большим разрешением, а также наличием множества мелких элементов, затрудняющих процесс анализа и контроля дефектов. Поэтому, для обработки таких изображений используются различные методы интеллектуального анализа данных, в том числе машинного обучения.

### Описание нейронной сети, используемой в ПК УОККР

Технологии глубинного обучения (deep learning) эффективно применяются для задач распознавания изображений, когда необходимо учитывать искажения и помехи исходных изображений. Далее рассмотрены основные принципы, лежащие в основе архитектуры «сеть-внутри-сети» (Network-in-Network), которая является развитием идеи сверточной нейронной сети и позволяет ускорить процесс обучения и уменьшить число ее параметров. В архитектуре обычной сверточной нейронной сети (CNN) слои свертки чередуются со слоями пулинга, что позволяет эффективно уменьшить пространство признаков. Первые слои пытаются извлечь из изображения примитивные признаки, такие как линии, углы и кривые, в то время как глубокие слои распознают все более сложные структуры. В итоге пространство признаков сжимается, в качестве последних слоев сети используются полносвязные, с помощью которых формируется итоговое разделение вероятностей принадлежности изображения к определенному классу [1].

Функция выхода слоя свертки выглядит следующим образом:

$$f_{i,j,k} = \max(\omega_k^T x_{i,j}, 0),$$

где  $\omega$  – вектор параметров,  $x$  – вектор сигналов предыдущего слоя,  $i, j$  – индексы сигнала,  $k$  – индекс канала. В основе архитектуры NiN лежат две ключевые особенности:

1. Вместо выполнения линейной свертки, сигналы с выхода предыдущего слоя подаются на вход многослойного персептрона (Multi Linear Perceptron), который сам по себе является нейронной сетью. Это помогает извлекать более абстрактные признаки, пользуясь данными со всех каналов предыдущего слоя. Другими словами, вместо ядра фильтра свертки, которое мы перемещаем, перемещается по пикселям исходного изображения многослойный персептрон – микро-нейронная сеть, спрятанная внутри слоя (отсюда название архитектуры) (рис. 2) [2]. Персептрон быстрее обучается, что уменьшает время обучения. Функции выходов многослойного персептрона выглядят следующим образом:

$$f_{i,j,k}^1 = \max(\omega_{k_1}^T x_{i,j} + b_{k_1}, 0),$$

$$f_{i,j,k}^n = \max(\omega_{k_n}^T x_{i,j} + b_{k_n}, 0),$$

где  $\omega$  – вектор параметров,  $x$  – вектор сигналов предыдущего слоя,  $i, j$  – индексы сигнала,  $k$  – индекс канала,  $b$  – смещение,  $n$  – номер слоя.

2. Последний слой имеет на выходе столько каналов, сколько классов объектов необходимо распознавать. Затем сигналы проходят через слой пулинга, который усредняет значения всех каналов, и в итоге попадают на входы softmax слоя, который выдает итоговый результат работы сети. Согласно различным оценкам, в полно-связных слоях сверточных нейронных сетей содержится до 90 % параметров. Отсутствие полносвязных слоев позволяет избавиться от такого недостатка [3].

Данные изменения позволяют значительно уменьшить количество параметров сети, тем самым понизив склонность к переобучению. Кроме этого, такая архитектура становится более устойчивой к различным трансформациям, по-

воротам и сдвигам исходных изображений. Для обучения сети используется метод обратного распространения ошибки (back-propagation), он подходит как для обучения сверточных сетей, так и многослойных персептронов.




Рис. 2. Архитектура нейронной сети Network-in-Network

### Тестирование применения ИС в ПК УОКР

Для поиска элементов на изображении используется метод скользящего окна. При его использовании задается конфигурация «окна обработки» – двумерной области, охватывающей конечное множество отсчетов входного изображения. В процессе обработки данное окно смещается по изображению, последовательно занимая все возможные положения.

Для каждого положения окна можно применить классификационную нейронную сеть, которая обучена на тех классах, объекты которых нужно детектировать, и, таким образом, если классификационная сеть говорит, что в данном окне объект есть, то он помечается соответствующим классом.

Недостатком данного подхода является то, что для прохождения окна по всему изображению и параллельного применения нейронной сети для каждого положения окна требуется дополнительное время.

Для тестирования модели используются полутоновые изображения интегральных схем ИС (рис. 3). В качестве обучающих изображений были использованы фрагменты изображений с отдельными элементами интегральных схем, которые равномерно распределены (рис. 4). При этом, объем обучающей выборки (training set) составил 4200 элементов,

тренировочной (validation set) и тестовой выборки (test set) – по 900 изображений.




Рис. 3. Примеры тестовых изображений ИС




Рис. 4. Примеры изображений ИС для обучения

### Выводы

Особенностями задачи анализа топологий микросхем является большой масштаб исходных изображений с множеством мелких деталей. Это значит, что большое значение имеет возможность системы работать с большими объемами входных данных. При применении нейронных сетей необходимо стремиться к уменьшению параметров сети, для того чтобы избежать переобучения и увеличить скорость обучения модели. Как показано в источнике [4], нейронные сети с архитектурой NiN показывают лучшие результаты точности при меньшем числе параметров.

Это является важным фактором, так как система будет затрачивать меньшее время на обучение, а значит, более эффективно использовать ограниченные машинные ресурсы. При этом описанная архитектура обладает основными преимуществами сверточных нейронных сетей – хорошо масштабируется, весьма эффективна для задач распознавания изображений, а также подходит для распараллеливания вычислений, но при этом обладает большей устойчивостью к искажениям.

ям исходного изображения, что особенно важно для систем технического зрения, применяемых в установках выпускаемых на предприятии ОАО «КБТЭМ-ОМО» [5], в частности в ПК УОККР предложенная архитектура нейронной сети NiN реализована с использованием библиотеки Tensorflow [6-7].

Существенным преимуществом оборудования управляемого ПК УОККР и разрабатываемого ОАО «КБТЭМ-ОМО» для производства СБИС перед зарубежными аналогами является то, что оно проектируется на единой конструкторско-технологической базе, реализуя полную аппаратную, программную и метрологическую совместимость всего комплекта установок, работающих в едином технологическом цикле для воплощения в кремнии критических технологий микроэлектронной промышленности.

### Литература

1. Convolutional Neural Networks for Visual Recognition (2015) [Online]. Available: <http://cs231n.github.io/convolutional-networks/>
2. Network In Network (1991) [Online]. Available: <https://arxiv.org/pdf/1312.4400v3.pdf>.
3. Network In Network architecture: The beginning of Inception (2017) [Online]. Available: <http://teleported.in/posts/network-in-network>.
4. An Analysis of Deep Neural Network Models For Practical Applications (1991) [Online]. Available: <https://arxiv.org/pdf/1605.07678v4.pdf>.
5. Достанко, А.П., Аваков, С.М., Агеев, О.А., Батура, М.П. (2016) Технологические комплексы интегрированных процессов производства изделий электроники. Минск: Беларуская навука. – 251 с.
6. Николенько, С., Кадуринов, А., Архангельская, Е. (2018) Глубокое обучение. СПб.: Питер, 480 с.
7. Tensorflow API documentation [Online]. Available: [/api\\_docs/python/tf/nn/softmax\\_cross\\_entropy\\_with\\_logits\\_v2](https://api_docs/python/tf/nn/softmax_cross_entropy_with_logits_v2).

### References

1. Convolutional Neural Networks for Visual Recognition (2015) [Online]. Available: <http://cs231n.github.io/convolutional-networks/>
2. Network In Network (1991) [Online]. Available: <https://arxiv.org/pdf/1312.4400v3.pdf>.
3. Network In Network architecture: The beginning of Inception (2017) [Online]. Available: <http://teleported.in/posts/network-in-network>.

4. An Analysis of Deep Neural Network Models For Practical Applications (1991) [Online]. Available: <https://arxiv.org/pdf/1605.07678v4.pdf>.
5. Dostanko, A.P., Avakov, S.M., Ageev, O.A., Batura, M.P. (2016) Tehnologicheskie komplek-syi integrirovannyih protsessov proizvodstva izdeliy elektroniki. Minsk: Belaruskaya navuka. – 251 s.
6. Nikolenko, S., Kadurin, A., Arhangelskaya, E. (2018) Glubokoe obuchenie. SPb.: Piter, 480 s.
7. Tensorflow API documentation [Online]. Available: [/api\\_docs/python/tf/nn/softmax\\_cross\\_entropy\\_with\\_logits\\_v2](https://api_docs/python/tf/nn/softmax_cross_entropy_with_logits_v2).

### RESUME

**S. Avakaw, A. Voranau, V. Ganchenko, A. Doudkin, A. Dedkov, V. Sholomicki**

#### **Methods of artificial intelligence in software control system for equipment of critical sizes inspection on the basis of computer vision**

In this paper the functional requirements and the structure of software control system for equipment of critical sizes inspection on the basis of computer vision are described. The artificial intelligence methods including Network-in-Network type neural networks and deep learning were applied for solving problems of analyzing images. The advantages of the architecture of Network-in-Network are considered. The first layers of the NiN try to extract primitive features from the image, such as lines, angles, and curves, while the deeper layers recognize more and more complex structures. As a result, the feature space is compressed. At the last layers of the network, fully connected layers are used. Application of Network-in-Network technology allows identifying effectively defects that is especially important for software engineering for equipment of critical sizes inspection of VLSI manufacturing based on submicron technology.

The developed software provides the following functions:

- image preprocessing taking into account design and technological restrictions;
- image processing and analysis with support of different video equipments;
- image analysis for the inspections of manufacturing operations;



- storage and access to data with the ability to import and export data in various formats;
- synthesis of the program for automatic operation mode;
- control of different mechanisms;
- data visualization.

The architecture of the software system was developed, providing the possibility of flexible adjustment of the general algorithm of image processing and analysis. The user can independently compose chains of simple algorithms to obtain more complex ones. It is also possible to connect external routines. The operation parameters and auto-

matic processing programs are stored in the database.

The software is used in the production of competitive precision equipment for VLSI manufacturing what determines its practical importance: for automatic photometry with precision laser focusing system; for automated microsize inspection system; for mask pattern coordinates measurement system, equipment for mask pattern generation and inspection.

*Надійшла до редакції 15.10.2018*